

基于双通道循环生成对抗网络的无人车夜视 红外视频彩色化

李佳豪^{1,2**}, 孙韶媛^{1,2*}, 吴雪平^{1,2}, 李大威^{1,2}

¹ 东华大学信息科学与技术学院, 上海 201620;

² 东华大学数字化纺织服装技术教育部工程研究中心, 上海 201620

摘要 在无人车夜视红外视频彩色化问题中,考虑到可同时利用单帧图像的信息和视频的帧间信息,提出了一种双通道循环生成对抗网络(DcCCAN)对夜视红外视频进行彩色化。DcCCAN是在循环一致生成对抗网络(CCAN)的基础上提出的双通道生成网络。双通道生成网络具有良好的图像特征提取能力,能够自动提取视频中待处理图像的特征,同时提取先前模型所生成图像的特征,然后将特征信息整合后生成一幅目标图像。通过在生成对抗性训练中引入循环一致性训练机制,可无监督地学习得到红外域图像到彩色域图像的映射关系,从而实现红外视频的彩色化。实验表明该方法能够为视频中的红外图像赋予自然的色彩信息和纹理信息,且满足实时性要求。

关键词 机器视觉; 红外视频彩色化; 双通道循环生成对抗网络; 双通道生成网络

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP55.091505

Unmanned Vehicle Night Infrared Video Colorization Based on Dual-Channel Cycle-Consistent Adversarial Networks

Li Jiahao^{1,2**}, Sun Shaoyuan^{1,2*}, Wu Xueping^{1,2}, Li Dawei^{1,2}

¹ College of Information Science and Technology, Donghua University, Shanghai 201620, China;

² Engineering Research Center of Digitized Textile & Fashion Technology, Ministry of Education, Donghua University, Shanghai 201620, China

Abstract In the task of unmanned vehicle infrared video colorization, considering the uniqueness of a single frame and the continuity of the entire infrared video, a dual-channel cycle-consistent adversarial network (DcCCAN) based colorization method is proposed. The dual-channel generation network we proposed is on the basis of cycle-consistent adversarial network (CCAN) and has good image feature extraction ability, which can automatically extract the features of the frame in the video, and at the same time can extract the features of the previous frame generated. By joint training of adversarial loss and cycle-consistent loss, the function from infrared domain image to color domain image can be learned by unsupervised learning methods and the colorization of the infrared video can be realized. The experimental results show that the proposed method can provide natural color information and texture information for the infrared images in the video, and meet the real-time requirements.

Key words machine vision; infrared video colorization; dual-channel cycle-consistent adversarial networks; dual-channel generation network

OCIS codes 150.1135; 100.2960; 350.4600

1 引言

夜间无人车在行驶过程中无法得到彩色视频信

息,无法准确感知无人车周边的环境,因此需要获取红外视频提高无人车在夜间行驶的环境感知能力。夜间无人车所获取的红外视频完全不同于可见光视

收稿日期: 2018-03-28; 修回日期: 2018-04-17; 录用日期: 2018-04-23

基金项目: 上海市科委基础研究项目(15JC1400600)、国家自然科学基金青年科学基金(61603089)、上海市青年科技英才扬帆计划(16YF1400100)

* E-mail: shysun@dhu.edu.cn; ** E-mail: jiahaoli0305@gmail.com

频,无色彩且纹理简单,对比度和信噪比低且图像模糊^[1]。乘坐夜间高速行驶的无人车的乘客,因为无法清楚地了解道路信息,很容易产生焦虑情绪。如果为无人车拍摄的红外视频实时地赋予接近真实场景的色彩和纹理信息,并呈现给乘客,乘客能够更清楚地了解道路信息,从而克服焦虑的情绪。同时,红外视频的彩色化结果有助于无人车理解道路状况,给出更加准确的驾驶策略,提高行车安全性能。

针对红外图像及视频的彩色化问题,目前比较成熟的方法是基于色彩传递的传统机器学习方法。色彩传递是将图像 A 和图像 B 合成一幅新的图像 B',使 B'同时具有 A 的色彩和 B 的形状等信息^[2],这需要人工设置关键帧和大量的人工干预。代中华等^[3-4]对视频关键帧进行 C 均值聚类,再引入 Fisher 评价算法^[5]进行图像分割,将关键帧图像的色彩信息传递到红外图像,实现彩色化。譙帅等^[6]采用改进的 KLT (Kanade-Lucas-Tomasi) 运动估计方法提取视频中的图像并跟踪特征点,将图像分为若干区域,然后通过色彩传递的方法按区域为图像上色。文献[3]和文献[6]所采用的传统机器学习方法需要人工设置大量的彩色关键帧,应用场景较为单一,不能满足实时性要求,且只能简单地将红外图像中的树木、草地赋予绿色,将天空赋予蓝色,将建筑物赋予黄色等,无法还原真实的彩色场景。谷小婧等^[7]提出了基于支持向量回归(SVR)和多尺度特征提取的红外图像彩色化方法,首先对红外图像进行多尺度特征提取,然后通过支持向量回归模型学习红外图像到彩色图像的映射关系,但这只适用于单幅红外图像的彩色化,且同样采取对图像中的场景按类别简单上色的策略,与实际场景有很大偏差。

生成对抗网络(GAN)模型在图像生成、图像翻译、图像复原等领域取得了巨大成功^[8]。Isola 等^[9]提出了条件约束对抗网络(CAN),可将两种类型的图像相互转化,首先构建 A 类型图像与 B 类型图像一一匹配的数据集,再将数据集输入网络模型,迭代学习后即可得到 A、B 图像可相互映射的参数模型。Zhu 等^[10]在 Isola 等的基础上提出了循环一致对抗网络(CCAN),该网络无需将 A、B 类型的图像一一匹配,通过将对抗损失与循环一致性损失相结合可无监督学习得到 A、B 两种类型图像的映射关系。以上两种方法可以实现图像不同风格之间的相互转换,而红外图像的彩色化问题也可以看成将一幅红外图像转化为彩色图像,因此本文采用循环一致对抗的思想对红外视频进行彩色化。

本文提出了一种将红外视频映射到彩色视频的方法,该方法能够真实还原红外视频中各个场景的纹理和色彩。考虑到红外视频彩色化问题中红外视频中相邻两帧之间的图像场景差别较小,因此彩色化后的视频中相邻两帧图像也应十分相似,受循环一致对抗神经网络^[10]的启发提出了双通道循环生成对抗网络(DcCCAN)。该网络采用的双通道生成网络模型在原有生成模型的基础上增加了一个权值共享的卷积网络通道,生成网络提取待转化红外图像特征的同时,可提取上一帧彩色化结果图像的特征,使网络模型具备了利用视频帧间信息的能力^[11-12],更适用于对红外视频进行彩色化处理。与不能利用帧间信息的深度学习模型相比,本文模型的彩色化结果更加接近真实场景。由于红外相机和彩色相机的成像原理及成像速率不同^[13],很难将红外图像与该图像对应的彩色图像一一匹配,因此在对抗生成性损失的基础上,引入循环一致性损失,于是在网络的训练过程中不需要将红外图像与彩色图像一一匹配,实现了网络的无监督训练。本文方法无需人工设置彩色关键帧,实时性能优越,且更加适用于视频处理,彩色化结果更加自然。

红外视频彩色化是通过训练双通道循环生成对抗网络实现的。首先将双通道生成网络 G, F 和判别网络 D_x, D_y 构成双通道循环生成对抗网络模型,再将对抗性损失和循环一致性损失的目标函数相结合调整各个网络层的权值,最终完成整体网络模型的训练。第 2 节和第 3 节将着重介绍模型的网络结构和训练的目标函数。

2 网络结构

网络结构包含四个子网络模型,分别是将红外视频中的红外图像生成为彩色图像的双通道生成网络 $G: X \rightarrow Y$ 、将彩色视频中的彩色图像生成为红外视频的双通道生成网络 $F: Y \rightarrow X$ 、用于判断输入图像是否为红外图像的判别网络 D_x 和用于判别输入图像是否为彩色图像的判别网络 D_y 。以上四个子网络模型通过循环对抗的方式构成训练模型。采用生成对抗损失进行训练的同时,引入循环一致性损失,驱使生成的红外图像 $F[G(x)]$ 与真实的红外图像相似,生成的彩色图像 $G[F(y)]$ 与真实的彩色图像相似,对网络进行循环一致性训练,最终实现模型的无监督训练。

2.1 双通道生成网络设计

视频中相邻帧图像十分相似,在视频处理中

由网络生成的前一帧目标域图像包含很多有用信息,鉴于此,提出了更加适用于视频图像相互转化的双通道生成网络。该网络同时提取当前帧待转化图像和前一帧转化完成的图像的特征,生成当前帧转化后的图像。如图1所示,双通道生成网络主要包含三部分:双通道卷积网络(ConvNet)、残差网络(ResNet)和反卷积网络(deConvNet)。双通道卷积网络包含两个权值共享的卷积网络,一个卷积网络用于提取待转化图像(frame)特征,另一个卷积网络提取该生成网络上一轮生成结果图的特征。最后反卷积网络将整合后的特征张量生成一张目标域图像。利用双通道卷积网络的结构,生成网络能够利用帧间信息生成一张目标域图像。




图1 双通道生成网络

Fig. 1 Dual-channel generation network

2.2 判别网络

如图2所示,判别网络由一个四层卷积网络构成。首先对输入图像进行四次卷积操作,得到一张尺寸为 $32\text{ pixel} \times 32\text{ pixel}$ 的特征图,然后将特征图输入sigmoid交叉熵函数^[14],判断输入图像是否符合目标图像的分布。本文模型中包含两个判别网络,分别是判断输入图像是否为红外图像的判别网络 D_X 和判别输入图像是否为彩色图像的判别网络 D_Y 。



图2 判别网络

Fig. 2 Discriminative network

2.3 双通道循环生成对抗网络

本文的目标是从训练样本红外视频数据集 $\{x_i\}_{i=1}^N \in X$ 和彩色视频数据集 $\{y_i\}_{i=1}^M \in Y$ 中学习

到将红外视频映射到彩色视频的函数关系 $G: X \rightarrow Y$ 。图3包括将红外视频映射到彩色视频的双通道生成网络 $G: X \rightarrow Y$ 和彩色视频映射到红外视频的双通道生成网络 $F: Y \rightarrow X$,同时引入两个对抗判别网络 D_X 和 D_Y , D_X 用于区分真实红外图像 $\{x\}$ 和彩色图像生成的红外图像 $\{F(y)\}$, D_Y 用于区分真实彩色图像 $\{y\}$ 和红外图像生成的彩色图像 $\{G(x)\}$ 。采用双通道生成网络,该网络输入待转化图像和该网络上一轮生成的图像,输出目标图。例如双通道生成网络 G 输入图像是红外图像 x_i 和 G 网络上一轮生成的彩色图像 $G(x_{i-1})$,输出图像是 x_i 的彩色化结果 $G(x_i)$ 。生成网络的损失函数由两部分组成:1)用于比较生成图像分布与目标图像分布的对抗性损失 L_{GAN} ,如图3(a)所示;2)用于减小生成网络 G 、 F 映射空间的循环一致性损失 L_{cyc} ,如图3(b)所示,其中 y_i 与 $G[F(y_i)]$ 之间或者 x_i 与 $F[G(x_i)]$ 之间越相似,则循环一致性损失 L_{cyc} 越小。对抗性损失 L_{GAN} 与循环一致性损失 L_{cyc} 的定义将在第3节着重介绍。

$$G(x_{i-1}) + x_i \xrightarrow{\text{DcGN};G} G(x_i) + F(y_{i-1}) \xrightarrow{\text{DcGN};F} F[G(x_i)], \quad (1)$$

$$x_i, F[G(x_i)] \rightarrow L_{cyc}, \quad (2)$$

$$F(y_{i-1}) + y_i \xrightarrow{\text{DcGN};F} F(y_i) + G(x_{i-1}) \xrightarrow{\text{DcGN};G} G[F(y_i)], \quad (3)$$

$$y_i, G[F(y_i)] \rightarrow L_{cyc}, \quad (4)$$

$$x_i, F(y_i) \xrightarrow{D_X} \text{loss}; L_{GAN}, \quad (5)$$

$$y_i, G(x_i) \xrightarrow{D_Y} \text{loss}; L_{GAN}. \quad (6)$$

(1)式和(2)式表示计算红外图像 x_i 的循环一致性损失的过程。首先将红外图像 x_i 和前一帧彩色化结果 $G(x_{i-1})$ 同时输入双通道生成网络 G (DcGN:G),得到彩色化结果图 $G(x_i)$;再将前一帧由彩色图像生成的红外图像 $F(y_{i-1})$ 与 $G(x_i)$ 输入DcGN:F,得到 $G(x_i)$ 生成的红外图像 $F[G(x_i)]$,并与 x_i 相比较,计算循环一致性损失 L_{cyc} 。(3)式和(4)式表示计算彩色图像 y_i 的循环一致性损失的过程,与红外图像 x_i 循环一致性损失计算过程相似,不再赘述。(5)式和(6)式表示对抗性损失 L_{GAN} 的计算过程,判别网络 D_X 判别红外图像 x_i 和 F 生成的红外图像 $F(y_i)$ 是否符合红外图像的分布并计算损失函数,判别网络 D_Y 判别彩色图像 y_i 和 G 生成的彩色图像 $G(x_i)$ 是否符合彩色图像的分布并计算损失函数。

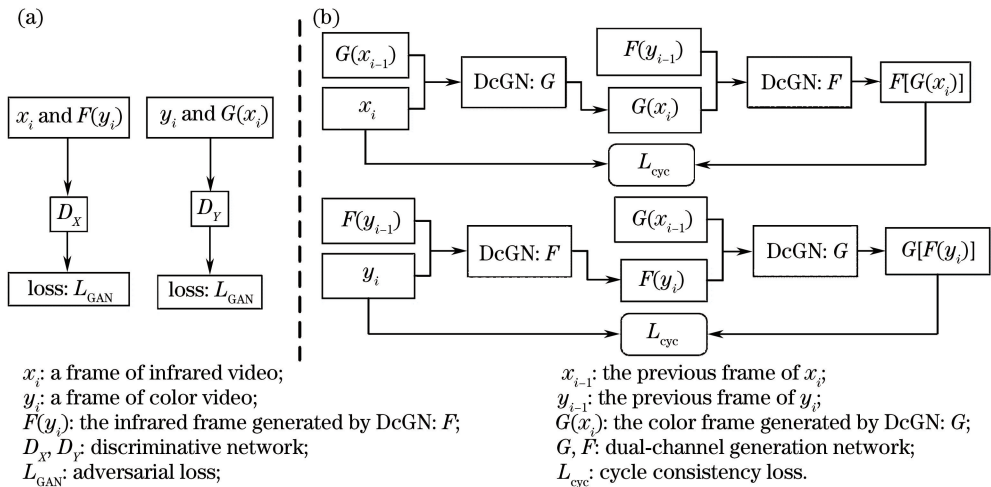


图3 训练流程图

Fig. 3 Flow chart of training

3 目标函数

目标函数包括两个方面,分别是对抗性损失 L_{GAN} 和循环一致性损失 L_{cyc} 。对抗性损失使双通道网络能够学习到目标域图像的分布,循环一致性损失使网络能够准确地将输入图像映射到目标图像。

3.1 对抗性损失

将对抗性损失分别应用于两个双通道生成网络 G 和 F 。对于双通道生成网络 $G: X \rightarrow Y$ 及其判别网络 D_Y ,将损失函数定义为

$$L_{GAN}(G, D_Y, X, Y) = E_{y \sim p_{data}(y)} [\log D_Y(y)] + E_{x \sim p_{data}(x)} \{\log \{1 - D_Y[G(x)]\}\}. \quad (7)$$

生成网络 G 将红外图像生成符合彩色视频 Y 分布的彩色图像 $G(x)$,判别网络 D_Y 区分真实彩色图像 $\{y\}$ 和红外图像生成的彩色图像 $\{G(x)\}$ 。该损失函数的目标是最小化 $G(x)$ 并最大化 D_Y ,如 $G^* = \arg \min_G \max_{D_Y} L_{GAN}(G, D_Y, X, Y)$ 。对于生成网络 $F: Y \rightarrow X$ 及其对应的判别网络 D_X ,同样引入类似的对抗性损失,如 $F^* = \arg \min_F \max_{D_X} L_{GAN}(G, D_X, Y, X)$ 。

3.2 循环一致性损失

理论上,对抗性损失能够使生成网络 G 和生成网络 F 分别学习到向目标数据分布 Y, X 的映射方法。然而,由于网络的学习能力十分强大,可以将同一张输入图像映射到目标域中任意一幅图像。因

此,单靠对抗性损失不能保证学习函数能够将一张红外图像 x_i 映射到期望的彩色图像 y_i 。为了进一步减小可能映射关系的空间,网络的映射关系应该是循环一致的。如图3所示,对于红外视频中的每一帧图像 x_i ,通过循环一致的网络构架都映射到原始图像,如 $x_i + G(x_{i-1}) \rightarrow G(x_i) \rightarrow F[G(x_i)] \approx x_i$ 。循环一致性损失定义为

$$L_{cyc}(G, F) = E_{x \sim p_{data}(x)} \{\|F[G(x)] - x\|_1\} + E_{y \sim p_{data}(y)} \{\|G[F(y)] - y\|_1\}. \quad (8)$$

3.3 完整目标函数

完整目标函数为

$$L(G, F, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, Y, X) + \lambda L_{cyc}(G, F), \quad (9)$$

式中, λ 控制对抗性损失和循环一致性损失的权重。训练目标为

$$G^*, F^* = \arg \min_{F, G} \max_{D_X, D_Y} L(G, F, D_X, D_Y). \quad (10)$$

本文模型的训练可以看作对两个“自动编码器”的联合训练: $G \circ F: Y \rightarrow Y$ 和 $F \circ G: X \rightarrow X$ 。每个编码器都通过特定的结构实现:首先将图像映射到中间域图像表示,然后通过中间域图像映射到自身。这种设置使得生成对抗网络突破了图像转换时存在过多映射关系的瓶颈。本文中红外图像到红外图像映射的自动编码器 $X \rightarrow X$ 的中间域图像是彩色域图像 Y 。

表1 实验配置

Table 1 Experimental configuration

Project	CPU	Memory	GPU	Operating system	CUDA
Content	Intel i5-6600	16 GB	NVIDIAGTX1070	Ubuntu14.04	CUDA8.0

4 实验过程和结果

4.1 实验配置


实验的机器硬件配置如表 1 所示。将网络结构搭建在知名深度学习计算框架 TensorFlow 上, TensorFlow 将网络转化成计算图,通过反向传播实现学习训练。

4.2 实验数据

采用的视频数据由搭载在汽车上的 FLIR 红外摄像机以及 Logitech 彩色摄像机拍摄得到,其中红外视频在夜间校园中拍摄,彩色视频于白天在校园同一场景中拍摄。拍摄的原红外视频中每一帧的分辨率为 $160 \text{ pixel} \times 120 \text{ pixel}$,采用双三次插值的方法将每一帧放大到 $256 \text{ pixel} \times 256 \text{ pixel}$ 。拍摄的原彩色视频中每一帧的分辨率为 $1960 \text{ pixel} \times 1080 \text{ pixel}$,采用缩放和裁剪的方法将彩色视频的分辨率调整到 $256 \text{ pixel} \times 256 \text{ pixel}$ 。经过抽帧处理,得到由 4537 帧的户外场景红外视频和 3816 帧的相同户外场景彩色视频组成的数据集,其分辨率均为 $256 \text{ pixel} \times 256 \text{ pixel}$ 。数据集分为两部分,一部分是由 3816 帧红外视频和 3816 帧彩色视频组成的训练集,其他 721 帧图像组成测试集。

4.3 实验步骤

采用双通道循环生成对抗网络对无人车夜视红外视频进行彩色化。将采集到的红外视频和彩色视频作为训练集,对双通道循环生成对抗卷积网络不断迭代训练使得模型收敛,存储整个模型的参数,将测试红外视频输入模型中的生成网络 G ,输出彩色化后的视频结果。训练过程中,生成网络 G 、生成网络 F 、判别网络 D_x 和判别网络 D_y 均采用学习率为 0.0002、动量为 0.5 的 Adam 优化器对函数进行优化。实验流程如图 4 所示,首先利用红外视频和相同场景的彩色视频对整个网络模型进行训练,再将夜视测试视频输入训练完成的双通道生成网络模型 G ,即可得到彩色化后的视频,训练过程大约耗时 6 h。



DcCCAN: dual-channel cycle-consistent adversarial network;
DcGN: dual-channel generation network.

图 4 实验流程图

Fig. 4 Flow chart of experiment

4.4 实验结果和分析

测试结果如图 5 所示,第 1 行为使用车载红外摄像机在校园中拍摄的视频中随机选取的几帧图像,第 2 行为采用循环一致对抗网络对以上红外图像进行彩色化的结果,第 3 行为采用双通道循环生成对抗网络得到的彩色化结果。可以看出,使用 CCAN 对红外视频进行彩色化时,能够为红外图像赋予色彩信息和纹理,但是效果较为粗糙,不够准确,在路边停靠的汽车常被 CCAN 生成为树木或草地,路边的树木也常被生成为建筑物,道路边的绿色灌木也被错误地生成为红色灌木。本文采用了更加适用于视频处理的双通道生成网络,能够利用帧间信息,彩色化结果更加准确、清晰。如图 5 第 3 行图像所示,本文算法能够准确地赋予树木、草地、建筑物、天空及道路真实的颜色,同时也能较为准确地为路边的车辆赋予色彩及纹理。使用 TensorFlow 的时间函数对每幅图像的速度进行统计,循环一致对抗网络处理每幅图像大约需要 38 ms,本文网络略为复杂,处理每幅图像大约需要 45 ms,满足实时性要求,而使用色彩传递的彩色化方法^[3]处理每幅图像大约需要 318 ms,计算时间是本文算法的 4.6 倍。可见相对于传统方法,本文算法在计算速度指标上有大幅提升。

模型目标函数的收敛趋势如图 6 所示。通过 Tensorboard 工具输出得到迭代过程中(9)式所表示的完整目标函数的值,可以看到 DcCCAN 在模型迭代计算 500 次左右就能够迅速收敛,损失值从 1.77 下降到 0.5;在 1000~5000 的迭代训练中,损失值以波动的形式缓慢下降,约从 0.5 下降到 0.36;在 50000~500000 的迭代训练过程中,损失值同样呈波动的形式缓慢下降,最终损失值收敛在 0.27 左右。使用 CCAN 模型进行迭代学习时,模型损失的收敛趋势与 DcCCAN 相似。但经过大量迭代后,DcCCAN 能够利用帧间信息,所以能够收敛到更小的损失值。这体现在图像彩色化的一些细节上,如图 5 所示,DcCCAN 彩色化后的图像表现得更加和谐,而 CCAN 错误地将原图中绿色的灌木生成为红色的灌木,并且错误地将树木的一部分生成为白色。

5 结 论

针对红外视频彩色化问题,在循环一致对抗网络的基础上,提出了双通道循环生成对抗网络。该网络能够结合当前帧红外图像的信息和相邻帧彩色化结果的信息,保证每一个特征都蕴含了相邻帧的




图 5 红外视频彩色化结果

Fig. 5 Results of infrared video colorization




图 6 双通道循环生成对抗网络与循环一致生成对抗网络的完整目标函数值

Fig. 6 Full objective functions of DcCCAN and CCAN

信息,同时保持了视频信息的稳定性,从而获得较好的红外视频彩色化结果。该方法无需人工设置彩色关键帧图像,适用场景广,操作简便。实验证明该方法能够为视频中的红外图像赋予自然的色彩信息和纹理信息,且满足实时性要求。

参 考 文 献

- [1] Gao K J, Sun S Y, Yao G S, *et al.* Semantic segmentation of night vision images for unmanned vehicles based on deep learning [J]. *Journal of Applied Optics*, 2017, 38(3): 421-428.
高凯珺, 孙韶媛, 姚广顺, 等. 基于深度学习的无人车夜视图像语义分割[J]. *应用光学*, 2017, 38(3): 421-428.
- [2] Zhu L B, Sun S Y, Gu X J, *et al.* Image colorization based on color transfer and propagation [J]. *Journal of Image and Graphics*, 2010, 15(2): 200-205.
朱黎博, 孙韶媛, 谷小婧, 等. 基于色彩传递与扩展的图像着色算法[J]. *中国图象图形学报*, 2010, 15(2): 200-205.
- [3] Dai Z H, Sun S Y, Xu Z, *et al.* A colorization algorithm for vehicle infrared video [J]. *Infrared Technology*, 2010, 32(10): 595-600.
代中华, 孙韶媛, 许真, 等. 一种车载红外视频彩色化算法[J]. *红外技术*, 2010, 32(10): 595-600.
- [4] Do M N, Vetterli M. The contourlet transform: an efficient directional multiresolution image representation [J]. *IEEE Transactions on Image Processing*, 2005, 14(12): 2091-2106.
- [5] Weyrich N, Warhola G T. Wavelet shrinkage and generalized cross validation for image denoising [J]. *IEEE Transactions on Image Processing*, 1998, 7(1): 82-90.
- [6] Qiao S, Sun S Y, Gu X J, *et al.* Vehicle infrared video colorization based on contour tracking [J]. *Journal of Applied Optics*, 2012, 33(4): 727-732.
谯帅, 孙韶媛, 谷小婧, 等. 基于轮廓跟踪的车载红外视频彩色化方法[J]. *应用光学*, 2012, 33(4): 727-732.
- [7] Gu X, Sun S, Fang J, *et al.* Kernel based color estimation for night vision imagery [J]. *Optics Communications*, 2012, 285(7): 1697-1703.
- [8] Goodfellow I J, Pougetabadi J, Mirza M, *et al.* Generative adversarial networks [J]. *Advances in Neural Information Processing Systems*, 2014, 3: 2672-2680.
- [9] Isola P, Zhu J Y, Zhou T, *et al.* Image-to-image translation with conditional adversarial networks [EB/OL]. (2017-11-22) [2018-03-01]. <https://arxiv.org/abs/1611.07004>.
- [10] Zhu J Y, Park T, Isola P, *et al.* Unpaired image-to-image translation using cycle-consistent adversarial networks [EB/OL]. (2018-02-19) [2018-03-01]. <https://arxiv.org/abs/1703.10593>.
- [11] Yao G S, Sun S Y, Fang J A, *et al.* Depth estimation of night driverless vehicle scene based on infrared and radar [J]. *Laser & Optoelectronics Progress*, 2017, 54(12): 121003.
姚广顺, 孙韶媛, 方建安, 等. 基于红外与雷达的夜

- 间无人车场景深度估计[J]. 激光与光电子学进展, 2017, 54(12): 121003.
- [12] Wu S C, Zhao H T, Sun S Y. Depth estimation from monocular infrared video based on bi-recursive convolutional neural network[J]. Acta Optica Sinica, 2017, 37(12): 1215003.
吴寿川, 赵海涛, 孙韶媛. 基于双向递归卷积神经网络的单目红外视频深度估计[J]. 光学学报, 2017, 37(12): 1215003.
- [13] Li Z B, Guo C, Zhao P F, *et al.* Mode instability mitigation by counter-pumped scheme in high power fiber laser[J]. Chinese Journal of Lasers, 2017, 44(8): 0801010.
李泽标, 郭超, 赵鹏飞, 等. 高功率光纤激光器中反向抽运结构对模式不稳定的抑制[J]. 中国激光, 2017, 44(8): 0801010.
- [14] Pal N R. On minimum cross-entropy thresholding[J]. Pattern Recognition, 1996, 29(4): 575-580